

# Framework zur Prozessüberwachung von transientem und stationärem Verhalten

Chris Louen, AKS Universität Duisburg-Essen  
chris.louen@uni-due.de

Steven X. Ding, AKS Universität Duisburg-Essen  
steven.ding@uni-due.de

## Zusammenfassung

In diesem Beitrag wird ein Framework zur Prozessüberwachung von transientem und stationärem Prozessverhalten vorgestellt. Eine modellbasierte Fehlerdiagnose ist wegen der hohen Dynamik in der Transienz oft zu komplex und Ressourcen intensiv. Auch die Anwendbarkeit von klassische datenbasierte Fehlerdiagnosen ist eingeschränkt, da sie meistens Linearität voraussetzen. Bei Nichtlinearitäten kommt es deswegen entweder zu einer hohen Fehlalarmrate oder zu einer geringen Fehlerdetektionsrate. Jedoch enthalten sie oft Informationen über den Fehler bzw. Zustand des Prozesses, die in stationären Bereichen nicht verfügbar sind und können erheblichen Einfluss auf die folgenden Arbeitspunkte haben (z.B. langesEinschwingverhalten). Deswegen ist eine Überwachung von großer Wichtigkeit um die Sicherheit, Qualität und Zuverlässigkeit eines Prozess zu steigern, so wie die Betriebskosten zu senken. Das in diesem Beitrag vorgestellte Framework ermöglicht eine Überwachung der verschiedenen Prozessphasen und besteht dabei aus drei Teilen. Zu erst werden Merkmale mit Hilfe eines Hybrid Modells erstellt. Als zweites wird für jede Phase eine Support Vektor Machine basierte Fehlerdiagnose entworfen und zuletzt wird eine Prozessüberwachung entworfen, die Ergebnisse aus mehreren Phasen vereint.

## 1 Einleitung

Durch den steigenden Grad der Automatisierung von Prozessen steigt die Anzahl der Komponenten und Subsysteme stetig an. Auf der einen Seite resultiert die Installation von neuen Komponenten meist in einer erhöhten Anlagensicherheit und ist manchmal auch nötig auf Grund von gesetzlichen Vorschriften, wie z.B. der Begrenzung von Emissionen. Auf der anderen Seite nimmt die Häufigkeit der Instandhaltungsaktionen zu. Die in der Industrie eingesetzte präventive Instandhaltung legt feste Intervalle für die Instandhaltung jeder Komponente fest, ohne Berücksichtigung des aktuellen Zustands und ist dadurch Ineffizient. Doch ein fehlerfreier Betrieb kann trotzdem nicht garantiert werden und durch die steigende Komplexität ist die Ursache des Fehlers immer schwerer zu finden, was

die Dauer eines ungeplanten Stillstands erhöht. Beides verringert die Verfügbarkeit der Anlage, die ein wichtiger Faktor für die Rentabilität eines Prozesses ist. Die meisten Fehler treten aber nicht abrupt auf, sondern durchlaufen vorher eine Degradation, die es erlaubt die am Anfang noch akzeptable Veränderung durch eine Fehlerquelle bis hin zum Fehler und damit den Zustand der Komponente (ZK) zu verfolgen. Ein Überblick der so genannten zustandsbasierten Instandhaltung, die den ZK nutzt und offensichtlich hilft die Effektivität der Instandhaltung zu steigern, ist in [4] gegeben.

Normalerweise ist der ZK nicht direkt messbar, sondern versteckt in vielen Messgrößen und zusätzlich beeinflusst durch Rauschen und unbekannte Störungen. Dadurch wird eine Extraktion von Merkmalen nötig. Für eine genau Bestimmung des Zustands muss der Verursacher der Veränderung bekannt sein, da das gleiche Muster in den Merkmalen einen unterschiedlichen ZK bedeuten kann. Gerade in stationären Arbeitspunkten (AP) ist häufig nur eine Einschränkung der Ursache möglich. Viele Prozesse werden aber in mehreren AP betrieben und bei dem Wechsel von einem AP in den nächsten AP ergibt sich eine Transienz mit hoher Dynamik, die es ermöglicht die Ursache weiter einzugrenzen oder den Verursacher zu identifizieren.

In der Vergangenheit wurden eine Vielzahl an unterschiedlichen Lösungen entwickelt, welche sich anhand der Art des Prozesswissen in modellbasierte und datenbasierte Methoden unterteilen lassen. Die modellbasierten Methoden nutzen ein mathematisches Modell der Komponente oder des Prozesses und berechnen dessen Ausgangswerte. Durch einen Vergleich zwischen den Modell- und den echten Prozessgrößen wird ein so genanntes Residuum erstellt, das Informationen über den Fehler enthält [3]. Mit einem guten Wissen über die zugrunde liegende Physik oder Alterungsstruktur kann die Modellgenauigkeit sehr hoch sein und resultiert in einer hohen Genauigkeit der Fehlerdiagnose. Es ist jedoch bekannt, dass es schwer ist ein gutes Modell für sehr komplexe Prozesse zu entwickeln, besonders wenn das Wissen über die Physik des Prozesses begrenzt ist. Außerdem ist der Ressourcenbedarf für das Modell auf Grund von Nichtlinearitäten oft sehr hoch und dadurch nicht für Prozessnahe Komponente geeignet. für  $n$  verschiedene AP Alternativ kann für diese Fälle das Prozesswissen aus Prozessdaten der Vergangenheit gewonnen und in einen Diagnosealgorithmus transformiert werden. Die Prozessdaten werden in modernen Prozessanlagen permanent gesammelt und sind deshalb häufig verfügbar. Der Einsatz dieser Methoden beschränkt sich allerdings oft auf stationäre Prozesse. In den letzten Jahren wurden für die Überwachung von Batch Prozessen so genannten multistage/ multiphase Varianten entwickelt. Diese betrachten den Batch Prozess aber oft als ein Objekt oder setzen eine gleichbleibende Dauer voraus. Ein Überblick ist in [8] gegeben.

Dieser Beitrag präsentiert ein Verfahren zur ereignisdiskreten Prozessüberwachung mit einem Betrieb in mehreren AP durch eine Unterteilung des Prozesses in Phasen und deren Auswertung mit einer Support Vector Machine (SVM) basierten Fehlerdiagnose. Erweitert wird diese mit einer übergeordnete Prozessüberwachung, die durch Hinzunahme vorangegangener Phasen, die aktuellen Ergebnisse Interpretiert. Es werden SVMs für jede Phase mit historische Messdaten der Phase trainiert, um die optimale Trennebene

zwischen akzeptablem und inakzeptablem ZK und zur Isolation der Fehlerquelle zu finden. Im Anschluss wird der aktuelle ZK aus den SVMs bestimmt. Die Prozessüberwachung beobachtet den ZK über mehrere Phasen und ermöglicht eine Isolation der Fehlerquelle nach jeder Phase, was durch die Fehlerdiagnose einzelner Phasen nicht immer möglich ist. Außerdem wird gezeigt wie das Verfahren mit fehlenden Trainingsdaten verschiedener Prozesszustände umgehen kann.

Dieser Beitrag ist wie folgt organisiert. Zunächst wird in Abschnitt 2 die Motivation und Problemformulierung erläutert. Als nächstes werden die Grundlagen der SVM Varianten in Abschnitt 3 beschrieben, gefolgt von der Vorstellung des Frameworks zur Prozessüberwachung in Abschnitt 4. In Abschnitt 5 wird das vorgestellte Verfahren auf das Drei-Tank-System, einem Fehlerdiagnose Benchmark, angewendet. Beendet wird der Beitrag durch Abschnitt 6 mit einer Zusammenfassung.

## 2 Motivation und Problemformulierung

Auch wenn existierende modell- und datenbasierende Methoden für die Überwachung von Prozessen mit mehreren AP und den Transienten zwischen diesen für verschiedene Probleme eine gute Performanz zeigen, ist das benötigte Modell für das transiente Verhalten oft zu komplex oder es werden Messdaten von jeder Fehlerquelle mit unterschiedlichen ZK gebraucht. Bei datenbasierten Verfahren muss für viele Phasen des Prozesses eine eigene Diagnose entworfen werden und es wird oft eine feste Dauer vorausgesetzt. Ein weiteres Problem stellt der Ressourcenbedarf dar, der häufig zu groß für Prozessnahe Komponenten ist.

Die genannten Nachteile sollen durch das in diesem Beitrag vorgestellte Framework, welches für das Training Messdaten der neuen und der nicht mehr akzeptablen Komponente benötigt, behoben werden. Es unterteilt den Prozess in Phasen, die durch in den Phasen gewonnene Merkmale beschrieben und am Ende der Phase mit einer SVM basierten Fehlerdiagnose bewertet werden. Der Vorteil des Verfahrens ist die Einfachheit, der geringe Ressourcenbedarf, der Umgang mit unterschiedlichen Phasendauern und der modulare Aufbau, der es erlaubt einzelne Funktionen (Fehlerisolation, -analyse) auszulagern.

Wie bei allen datenbasierten Methoden wird das Prozesswissen durch historische Messdaten erlangt und ist für stationäre AP und den Transienten beim AP-Wechsel anwendbar. Die benötigten Messdaten sind auf Grund der permanenten Erfassung dieser in modernen Prozessleitsystemen schon vorhanden. Eine Unterteilung in Phasen, die oft durch Expertenwissen bekannt ist, wird benötigt. Da die Merkmale während einer Prozessphase erstellt und am Ende dieser verfügbar sind, wird eine ereignisdiskrete Prozessüberwachung bereitgestellt. Bei kurzen Phasendauern und Verfolgung des ZK ist eine effektive Prozessüberwachung möglich.

### 3 Support Vector Machine

Eine SVM ist eine datenbasierte Methode zur Lösung von Klassifizierungsproblemen, die als zwei Klassen SVM (2K-SVM) von Boser u.a. entwickelt [1] und von Schölkopf u.a. zu einer ein Klassen SVM (1K-SVM) Modifiziert [6] wurde. Dafür findet die SVM die optimale Hyperebene, die beide Klassen voneinander trennt, mit dem maximalen Abstand zu beiden Klassen bzw. die Hyperebene, welche die Klasse von dem Ursprung trennt, so dass der Abstand zu dem Ursprung maximal ist. Ein großer Vorteil der SVMs ist eine gute Generalisierbarkeit, weil das Ziel die Minimierung des strukturellen Risikos ist. Andere Methoden, wie Neuronale Netzwerke, verfolgen die Minimierung des empirischen Risikos.

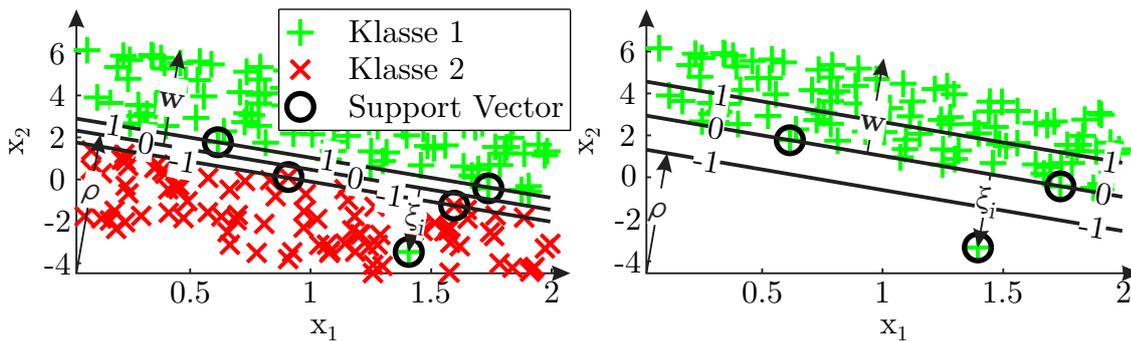


Abbildung 1: Soft Margin Support Vector Machine (2K-SVM links/ 1K-SVM rechts)

Eine Beschreibung der kompletten mathematischen Interpretation der SVMs ist in [2] bzw. [6] und ein Überblick im folgendem Abschnitt gegeben. Die SVM wird durch eine Hyperebene ( $\mathbf{w}, \rho$ ) beschrieben, die für die 2K-SVM so zwischen beiden Klassen positioniert ist, dass jeder Datenpunkt auf der zu seiner Klasse korrespondierenden Seite der Ebene liegt und für die 1K-SVM zwischen Ursprung und der Klasse. Der Parameter  $\mathbf{w} = (w_1, \dots, w_m)$  stellt eine Gewichtungsvektor und  $\rho$  ein Verschiebung der Hyperebene dar. Unglücklicherweise beeinflussen vereinzelte Störungen und Rauschen in den Trainingsdaten die Performanz sehr stark oder eine Lösung wird unmöglich da die Klassen sich überschneiden. Abb. 1 zeigt ein solches Beispiel, wo ein Datenpunkt im Training außerhalb der für ihre Klasse gesetzten Grenze ( $y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle - \rho) = 1 / \langle \mathbf{w}, \mathbf{x}_i \rangle = \rho$ ) liegen. Die Erweiterung, die mit Ausreißern umgehen kann, wird Soft Margin SVM genannt. Der so genannte Max Margin Algorithmus wird erweitert zu (2K-SVM links/ 1K-SVM rechts)

$$\begin{aligned}
 \min_{\mathbf{w}, \xi, \rho} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i; & \min_{\mathbf{w}, \xi, \rho} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i - \rho \\
 \text{so dass} \quad & y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle - \rho) \geq 1 - \xi_i; & \text{so dass} \quad & \langle \mathbf{w}, \mathbf{x}_i \rangle \geq \rho - \xi_i \\
 & \xi_i \geq 0, \quad i = 1, \dots, l; & & \xi_i \geq 0, \quad i = 1, \dots, l
 \end{aligned} \tag{1}$$

wobei  $y_i \in [-1, 1]$  den  $i$ -ten Datenpunkt der korrespondierenden Klasse zuordnet,  $\mathbf{x}_i \in \mathbb{R}^m$  gibt den  $i$ -ten Eingangsvektor mit  $m$  Messgrößen für jeden Zeitschritt an,  $\xi_i$  ist die slack Variable, welche fehlerhafte Datenpunkte im Trainingsdatenset zulässt und  $\nu$  ist der Pa-

parameter für den Kompromiss zwischen Struktur und Genauigkeit. Wird der Kompromissparameter als  $\nu = 0$  gewählt sind der Soft und Max Margin Algorithmus gleich. Um die Optimierungsprobleme (1) zu vereinfachen, können diese in eine duale Form überführt werden. Dafür werden die Probleme durch die korrespondierenden Lagrange Probleme ersetzt, im Bezug auf die Variablen  $\mathbf{w}$ ,  $\rho$  und  $\xi$  abgeleitet und in die Lagrange Probleme wieder eingesetzt. Die resultierenden dualen Formen sind gegeben durch

$$\max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle; \quad \min_{\alpha} \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (2)$$

$$\text{so dass } \sum_{i=1}^l y_i \alpha_i = 0; \quad \text{so dass } \sum_{i=1}^l \alpha_i = 1 \quad (3)$$

$$0 \leq \alpha_i \leq \frac{1}{\nu l}; \quad 0 \leq \alpha_i \leq \frac{1}{\nu l} \quad (4)$$

Die dualen Optimierungsprobleme sind nur noch von  $\alpha$  abhängig und dadurch einfacher als (1) zu lösen. Die Gewichtungvariable  $\mathbf{w}$  kann direkt aus den dualen und  $\rho$  aus den primären Problemen errechnet werden mit

$$\mathbf{w} = \sum_{i=1}^l y_i \alpha_i \mathbf{x}_i; \quad \mathbf{w} = \sum_{i=1}^l \alpha_i \mathbf{x}_i \quad (5)$$

$$\rho = \frac{\frac{1}{n_1} \sum_{i=1}^{n_1} \langle \mathbf{x}_{1,i}, \mathbf{w} \rangle + \frac{1}{n_2} \sum_{i=1}^{n_2} \langle \mathbf{x}_{2,i}, \mathbf{w} \rangle}{2}; \quad \rho = \frac{1}{n_1} \sum_{i=1}^{n_1} \langle \mathbf{x}_{1,i}, \mathbf{w} \rangle \quad (6)$$

wobei  $n_1$  und  $n_2$  die Anzahl und  $\mathbf{x}_{1,i}$  und  $\mathbf{x}_{2,i}$  die Eingangsdaten der Support Vektoren mit  $y_{1,i} = 1$ ,  $y_{2,i} = -1$  und korrespondierendem  $\alpha_i < \frac{1}{\nu l}$  sind. Unter Verwendung der vorangegangenen Ergebnisse wird die Entscheidungsregel für beide SVMs ausgedrückt als

$$\hat{y}_i = \text{sgn}(\langle \mathbf{w}, \mathbf{x}_i \rangle - \rho), \quad i = 1 \dots l \quad (7)$$

wobei  $\text{sgn}$  für die Signumfunktion steht, deren Ausgang gleich 1 für  $\langle \mathbf{w}, \mathbf{x}_i \rangle \geq \rho$  und gleich  $-1$  für  $\langle \mathbf{w}, \mathbf{x}_i \rangle < \rho$  ist. Alle Datenpunkte mit  $\hat{y}_i = 1$  sind Teil der Klasse  $+1$  und alle Datenpunkte mit  $\hat{y}_i = -1$  sind Teil der Klasse  $-1$  bzw. nicht Teil der Klasse  $+1$ . Bislang wurden alle Klassifizierungen als linear trennbar angenommen, aber in vielen Fällen ist die optimale Trennung nur durch eine nichtlineare Hyperfläche zu erreichen. Ein effizienter Weg solche Probleme zu lösen ist die Kernel Repräsentation, welche ein implizite Transformation in einen höherdimensionalen Raum ist. Dadurch ändern sich die Optimierungen (2) zu

$$\max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j); \quad \min_{\alpha} \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (8)$$

wo  $K(\mathbf{x}_i, \mathbf{x}_j)$  die Kernelfunktion darstellt und die Nebenbedingungen (3), (4) bleiben unverändert. Dabei ist der Gausskernel ein leistungsfähiger und häufig genutzter Kernel

und gegeben durch

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{c}\right) \quad (9)$$

wobei der Parameter  $c$  den Geltungsbereich eines SV festgelegt.

## 4 Framework

In diesem Abschnitt werden die Hauptbestandteile des Frameworks erläutert. Es besteht aus drei Teilen: I) Erstellung der Merkmale, II) Fehlerdiagnose (Fehlerdetektion FD, Fehlerisolation FDI, Fehleranalyse FDIA) der Phasen und III) Überwachung des Prozesses über mehrere Phasen.

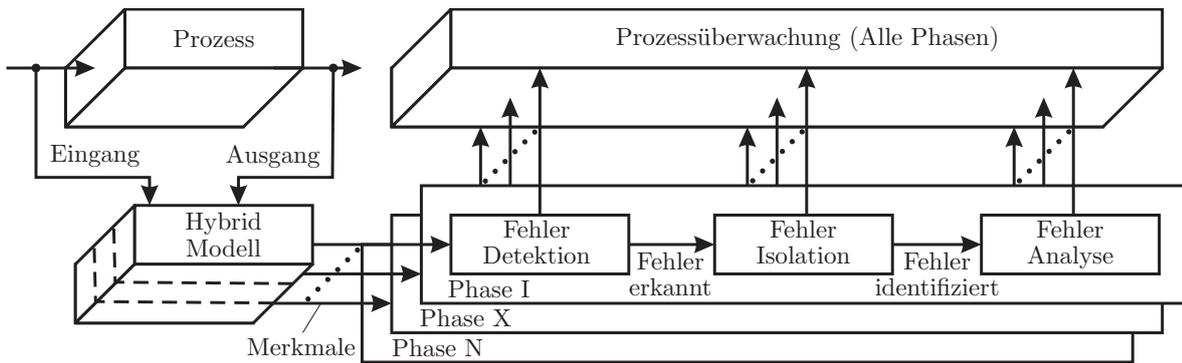


Abbildung 2: Schema des Framework zur Prozessüberwachung

### 4.1 Erstellung der Merkmale

Das in diesem Beitrag vorgestellte Framework unterteilt den Prozess in  $n$  Phasen, die jeweils über einen Zustand in einem diskretem Modell dargestellt werden. Abb. 3 zeigt ein Beispiel mit zwei AP und zwei Wechseln zwischen diesen, wobei die Transienten nochmal unterteilt wurden. Die Anzahl der Unterteilungen hängt vom Verlauf des Transienten ab und lässt sich beispielsweise mit einer veränderten Dynamik durch das Abschalten einer Pumpe begründen.

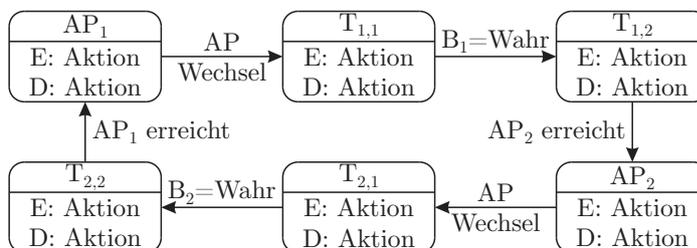


Abbildung 3: Hybrid Modell für einen Prozess mit zwei AP

Für jeden Zustand wird eine feste Anzahl von Merkmalen ermittelt, die zusammengefasst als Vektor den Prozesszustand beschreiben. Die Wahl der Merkmale sind von der Phase und dem Prozess abhängig und Größen wie die Phasendauer und die Differenz

einer Größe zwischen Phasen-Anfang und -Ende. Oft sind die Größen, die zu den diskreten Zeitpunkten gewonnen werden können, nicht ausreichend und dem Modell wird ein kontinuierlicher Modellteil hinzugefügt (Hybrid Modell), der Merkmale wie den Mittelwert oder die Abweichung von einer Solltrajektorie während der Phasen berechnen. Bei der Aktivierung eines Zustands wird einmalig eine Eingangsaktion E zur Initialisierung und, während der Zustand aktiv ist dauerhaft die Aktionen D zur rekursiven Berechnung der Merkmale ausgeführt. Eine rekursive Berechnung des Mittelwerts ist beispielsweise gegeben durch

$$\hat{\mu}_x(k) = \hat{\mu}_x(k-1) + \frac{1}{k} (x(k) - \hat{\mu}_x(k-1)) \quad (10)$$

Bei geeigneter Wahl der Phasen und Merkmale enthalten diese für eine Vielzahl von Prozessen ausreichend Informationen über das fehlerhafte und fehlerfreie System für eine effiziente Prozessüberwachung, die dank der einfachen Modellierung einen niedrigen Ressourcenbedarf aufweist. Besonders da in vielen Prozessen durch deren Ablaufsteuerung einen Teil des Modells bereits vorhanden ist.

## 4.2 Fehlerdetektion (FD)

Die 2K-SVM und 1K-SVM zeigen eine exzellente Performanz in der Ausreißer- und Fehlererkennung. Bei der FD können sie genutzt werden um das spezielle Muster einer fehlerhaften Komponente im Merkmalsvektor zu detektieren. Eine Übersicht der Verwendung von SVM in der Überwachung und Fehlerdiagnose ist in [7] gegeben. Das in diesem Beitrag vorgestellte Framework setzt die 2K-SVM in üblicher Weise ein. Es wird angenommen, dass die Trainingsdaten für eine Klasse ( $K_1$ : kein Fehler) durch eine Komponente mit akzeptabler Performanz und für die andere Klasse ( $K_2$ : Fehler) durch eine Komponente mit inakzeptabler Performanz gesammelt wurden.

Das durch die Prozessdaten von historische Instanzen gesammelte Prozesswissen wird durch die 2K-SVM in ein Diagnosealgorithmus transformiert. Wenn die Daten von einem stark verschlechtertem aber noch akzeptablen und dem gerade so inakzeptablen ZK verfügbar sind, detektiert die SVM die Fehler mit hoher Genauigkeit. In der Praxis sind diese Daten aber nur selten vorhanden und manchmal sind nur die Daten der neuen, d.h. keine Einwirkung durch die Fehlerquellen und der inakzeptablen Komponente verfügbar. Dann ist die übliche Strategie der SVM, die Trennebene mit möglichst großem Abstand zu beiden Klassen zu platzieren, nicht die beste Wahl. Eine Trennebene, die einen maximalen Abstand zu  $K_1$  und minimalen zu  $K_2$  hat, ist realistischer und wird in dem vorgestellten Framework genutzt. Um das resultierende Optimierungsproblem zu erhalten wird (2) im linearen Fall, (8) im nichtlinearen Fall eingesetzt und nur (6) wird ersetzt durch.

$$\rho = - \max_{i \in n_2} \langle \mathbf{x}_{i,2}, \mathbf{w} \rangle. \quad (11)$$

### 4.3 Fehlerisolation (FDI)

Die Unterscheidung zwischen verschiedenen Fehlerquellen durch die Lösung von mehreren 1K-SVMs, 2K-SVMs oder anderen Zweiklassenverfahren nach dem Eins gegen Eins (EGE) oder Eins gegen den Rest (EGR) Verfahren zeigt bei geeigneter Wahl der Reihenfolge gute Resultate [7]. Dabei wird die optimale Trennebene zwischen den beiden Klassen bzw. zwischen der Klasse und allen anderen im Training bestimmt und der Reihe nach jede Fehlerquelle überprüft. Erkannt werden die unterschiedlichen Muster der verschiedenen Fehlerquellen. Wie in der FD wird angenommen, dass die Trainingsdaten für jede Fehlerquellen durch Komponenten mit akzeptablem und inakzeptablem Zustand gesammelt wurden.

Die Isolation der einzelnen Fehlerquellen ist sehr gut für die komplette Degradation durch eine Fehlerquelle, wenn die Trainingsdaten ausreichend viele unterschiedliche ZK enthalten. Unter der Annahme aus der FD, dass nur die Daten der neuen und der inakzeptablen Komponente im Training verfügbar sind, ist die Degradation normalerweise nicht ausreichend beschrieben und möglicherweise lässt sich die Fehlerquelle erst bestimmen, wenn der ZK inakzeptabel geworden ist. Doch für eine effiziente Überwachung muss die Fehlerquelle schon in einem früherem ZK bekannt sein.

Das in diesem Beitrag vorgestellte zwei gegen den Rest (ZGR) Verfahren löst dieses Problem indem für jede Fehlerquelle eine 1K-SVM mit den Trainingsdaten der neuen Komponente und des inakzeptablen ZK trainiert und die Parameter für den eingesetzten Gaußskern konservativ gewählt werden. Dadurch wird auch die Fehlerquelle der Veränderung für Komponenten mit akzeptablem ZK isoliert. Ob es sich dabei um eine neue oder eine bereits gealterte Komponente handelt kann aus der FD bestimmt werden und ist Teil der Fehleranalyse. Trainingsdaten mit akzeptablem Zustand eine Fehlerquelle können genutzt werden, um durch weniger konservative Wahl der Kernparameter die Grenzen der Fehlerklasse enger an den wirklichen Verlauf zu bringen und dadurch die Isolation zu verbessern. Durch den Einsatz der 1K-SVM kann es besonders am Anfang der Degradation oder bei mehreren Fehlerquellen, welche in der Phase das gleiche Muster in den Merkmalen aufweisen, dazu kommen, dass die Isolation mehreren mögliche Fehlerquellen bestimmt. Außerdem ist es bei der gleichzeitigen Einwirkung von mehreren Fehlerquellen möglich, dass keine Fehlerquelle erkannt wird. Eine Lösung der Problematik wird durch die weiteren Schritte des Frameworks gelöst.

### 4.4 Fehleranalyse (FDIA)

Für die Bestimmung des aktuellen Zustands aus einer SVM werden unterschiedliche Methodiken vorgeschlagen. In diesem Framework wird das in [5] vorgestellte Verfahren genutzt, welches die Distanz des Merkmalsvektor zur SVM Trennebene als Maß für den aktuellen Zustand heranzieht. Durchgeführt wird das Verfahren mit der SVM aus der FD. Die Distanz ist ein Zwischenergebnis der SVM und gegeben durch

$$\hat{d}_i = \langle \mathbf{x}_i, \mathbf{w} \rangle - \rho, \quad i = 1 \dots l. \quad (12)$$

Die Interpretation der Distanz ist, dass das Muster in den Merkmalen durch die Verschlechterung des ZK dem Muster des inakzeptablen ZK immer ähnlicher wird und sich dadurch die Distanz zur Trennebene verringert. Die Distanz stellt also Informationen über den ZK bereit, die z.B. für eine bessere Instandhaltungsplanung oder Fehlertolerante Regelung genutzt werden kann.

Wenn bei gleichzeitiger Einwirkung mehrerer Fehlerquellen durch die FDI keine Fehlerquelle erkannt wurde, werden diese über die Bestimmung der Distanz zu den Trennebenen in der FDI den Fehlerquellen zugeordnet, denen sie am nächsten sind.

## 4.5 Prozessüberwachung

In der Prozessüberwachung wird eine Überwachung des ZK unter Berücksichtigung mehrerer Phasen durchgeführt. Nicht jede Verschlechterung des ZK kann in jeder Phase detektiert und isoliert werden. Durch eine Überwachung des ZK bevor er nicht mehr nicht mehr akzeptabel wird, ist es möglich vorangegangener Phasen dafür einzusetzen. Die Isolation ist möglich, da nur das Muster der aktuell wirkenden Fehlerquelle in allen Phasen vorhanden ist und die Muster verschiedener Fehlerquellen sich nur in einigen Phasen gleichen. Durch die Isolation ist dann auch der aktuelle ZK durch die FDIA bestimmbar. Für Fehlerquellen, die sich in der aktuellen Phase nicht auswirken, wird der Stand der letzten Phasen angenommen.

## 5 Benchmark Studie

Die für die chemische Industrie typischen Charakteristiken von Pumpe, Rohren und Tanks werden durch das Drei-Tank-System nachempfunden. Da Leckagen, Verstopfungen, Sensor- und Aktorfehler erheblichen Einfluss auf die Umgebung haben können, ist eine erfolgreiche FDIA von besonderem Interesse. In diesem Beitrag werden drei Leckage-  $f_{L_i}$ , zwei Pumpen-  $f_{P_i}$ , drei Sensor-  $f_{S_i}$  und drei Verstopfungsfehler  $f_{P_{ij}}$  betrachtet, wobei  $i$  den Tank und  $ij$  die Verbindung zwischen den Tanks  $i$  und  $j$  angibt.

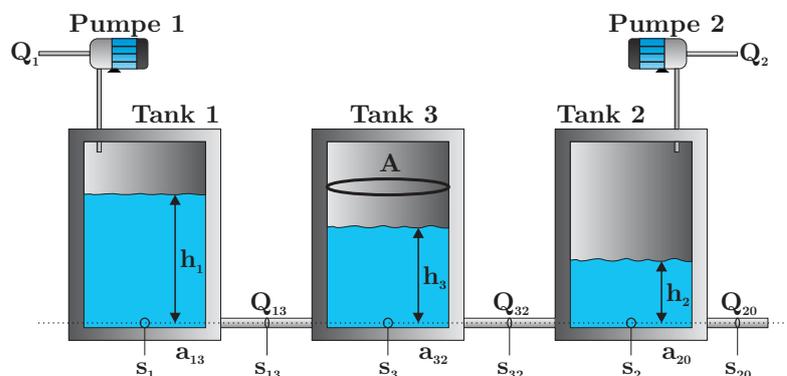


Abbildung 4: Aufbau des Drei-Tank-Systems

Abb. 4 zeigt den Aufbau des Drei-Tank-Systems. Die Volumenänderung in jedem Tank

kann durch die eingehenden und ausgehenden Volumenströme beschrieben werden

$$\begin{aligned} A\dot{h}_1 &= \theta_{P_1}Q_1 - Q_{13} - Q_{L_1}, & A\dot{h}_2 &= \theta_{P_2}Q_2 + Q_{32} - Q_{20} - Q_{L_2}, \\ A\dot{h}_3 &= Q_{13} - Q_{32} - Q_{L_3} \end{aligned} \quad (13)$$

wobei  $Q_i$  der eingehende Volumenstrom,  $Q_{L_i}$  der ausgehende Volumenstrom durch eine Leckage und  $h_i$  der Füllstand des Tanks  $i$  sind. Der Pumpenfehler ist durch  $\theta_{P_i}$ , der Querschnitt der Tanks durch  $A$  und der Volumenstrom zwischen den Tanks  $i$  und  $j$  bzw. der ausgehende Volumenstrom durch  $Q_{ij}$  gegeben. Die Volumenströme zwischen den Tanks und die Leckage Volumenströme ergeben sich aus dem Torricellischem Gesetz

$$Q_{13} = \theta_{P_{13}}a_{13}s_{13} \operatorname{sgn}(h_1 - h_3) \sqrt{2g|h_1 - h_3|}, \quad (14)$$

$$Q_{32} = \theta_{P_{32}}a_{32}s_{32} \operatorname{sgn}(h_3 - h_2) \sqrt{2g|h_3 - h_2|}, \quad Q_{20} = \theta_{P_{20}}a_{20}s_0 \sqrt{2gh_2} \quad (15)$$

$$Q_{L_1} = \theta_{L_1} \sqrt{2gh_1}, \quad Q_{L_2} = \theta_{L_2} \sqrt{2gh_2}, \quad Q_{L_3} = \theta_{L_3} \sqrt{2gh_3} \quad (16)$$

dabei sind  $s_i, s_{ij}$  die Querschnittsöffnungen,  $a_{ij}$  eine Skalierungskonstanten,  $\theta_{P_{ij}}, \theta_{L_i}$  ein multiplikativer Fehler der Verbindungen zwischen Tank  $i$  und  $j$  bzw. der Leckage des Tanks  $i$  und  $g$  die Gravitationskonstante. Der gemessene Füllstand  $h_{i,\text{mes}}$  ergibt sich aus dem realen Füllstand und einem multiplikativen Fehler  $\theta_{S_i}$ .

$$h_{1,\text{mes}} = \theta_{S_1}h_1, \quad h_{2,\text{mes}} = \theta_{S_2}h_2, \quad h_{3,\text{mes}} = \theta_{S_3}h_3 \quad (17)$$

Es wurde für diesen Beitrag angenommen, dass der Prozess in den zwei AP (AP<sub>1</sub> :  $w_{h_1} = 0,4$  m,  $w_{h_2} = 0,3$  m; AP<sub>2</sub> :  $w_{h_1} = 0,15$  m,  $w_{h_2} = 0,1$  m) betrieben wird, wobei AP<sub>1</sub> und AP<sub>2</sub> je für die Dauer von 100 s ausgeführt werden und dann der AP gewechselt wird. Die Dauer beginnt nicht beim setzen der neuen Sollwerte, sondern wenn beide Pumpen mit Teillast laufen, da die Abweichung von Soll- und Istwert klein ist. Durch Rauschen und die Fehlereinwirkung ist die Dauer der Transienten immer unterschiedlich nur die Dauer der näherungsweise stationären AP ist konstant. Als inakzeptabler ZK wurde für alle Fehlerquellen eine Änderung des Zustands um  $f_i = 10\%$  angenommen.

Der Prozessverlauf des Beispiels wurde in 6 Phasen unterteilt. Der besseren Darstellung halber wurden für jede Phase nur zwei Merkmale gewählt, auch wenn mehr Merkmale zu einem besseren Ergebnis geführt hätten. Je eine Phase stellen die beiden AP (AP<sub>1</sub> : P<sub>3</sub>, AP<sub>2</sub> : P<sub>6</sub>), die wegen der konstanten Höhen  $h_1, h_2$  und der Phasendauer über den Mittelwert der Volumenströme durch die Pumpen  $\bar{Q}_1, \bar{Q}_2$  überwacht werden. Der Transient von AP<sub>2</sub> zu AP<sub>1</sub> wird unterteilt in P<sub>1</sub> (beide Pumpen laufen mit voller Last) und P<sub>2</sub> (nur Pumpe 2 läuft mit voller Last), die gewählten Merkmale sind die Phasendauer  $\Delta t$  und die mittlere Höhe  $\bar{h}_3$ . Der Transient von AP<sub>1</sub> zu AP<sub>2</sub> wird auch in zwei Phasen unterteilt. In der Phase P<sub>4</sub> sind beide Pumpen abgeschaltet und in der Phase P<sub>5</sub> ist nur noch die Pumpe von Tank 1 abgeschaltet, wie bei dem anderen Transienten sind die Merkmale die Phasendauer  $\Delta t$  und die mittlere Höhe  $\bar{h}_3$  in Tank 3.

Für die FD in den Phasen wurde ein linearer und für die FDI eine Gausskernel ein-

gesetzt. Abb. 5 zeigt das Ergebnis der FD (links) und FDI (rechts) für die zum  $f_{L_2}$  gehörenden SVMs in der Phasen  $P_1$  und die Trainingsdaten verschiedener Fehlerquellen ( $f_i = 10\%$ ). Die Veränderung des ZK  $f_{L_2}$  ist in dem Beispiel  $f_{L_2} = 5\%$ . Es ist ersichtlich, dass eine Isolation der aktuellen Fehlerquelle  $f_{L_2}$  nicht möglich ist. Die Fehlerquellen können nur auf  $f_{L_2}$ ,  $f_{L_3}$  oder  $f_{P_2}$  eingegrenzt werden.

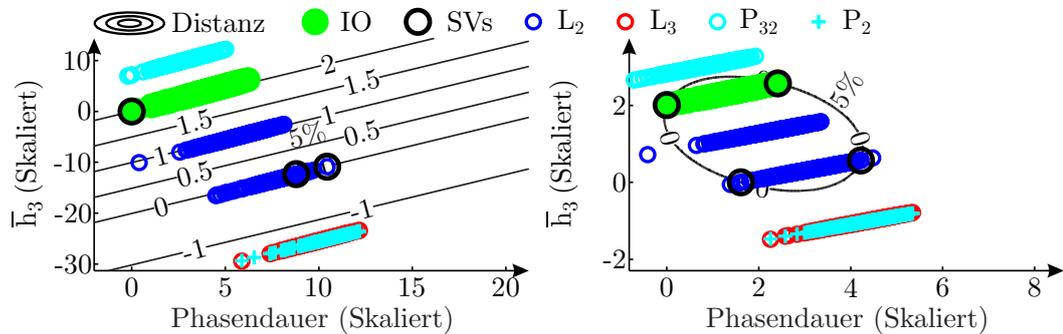


Abbildung 5: Trainingsdaten, der aktuelle ZK  $f_{L_2} = 5\%$  und die Ergebnis der FD (links) mit linearer Trennung und FDI mit Gausskernel für  $L_2$  in  $P_1$

Die Abb. 6 zeigt die Ergebnisse der FD (links) und FDI (rechts) für die Phase  $P_4$ . Da die beiden Pumpen in dieser Phase abgeschaltet sind wirkt sich eine Veränderung der Pumpe  $f_{P_2}$  nicht aus und das Muster des Fehlers  $f_{L_3}$  unterscheidet sich so stark von dem des Fehlers  $f_{L_2}$ , dass dieser eindeutig Isoliert werden kann.

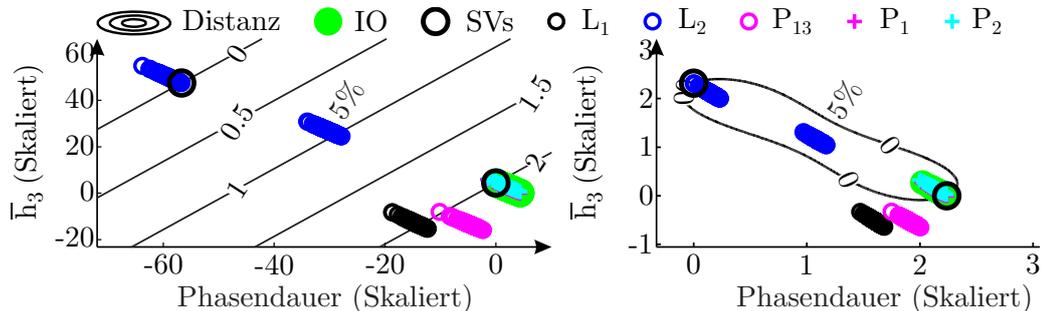


Abbildung 6: Trainingsdaten, der aktuelle ZK  $f_{L_2} = 5\%$  und die Ergebnis der FD (links) mit linearer Trennung und FDI mit Gausskernel für  $L_2$  in  $P_4$

Die Veränderung des ZK in Phase  $P_1$  ist durch die Distanz zur Trennebene der FD für  $f_{L_2}$  mit  $\hat{d} = 1$  und für  $f_{P_2}$  mit  $\hat{d} = 1,46$  gegeben. Durch die Phase  $P_4$  aus dem letzten Durchlauf des Batch Prozess ist  $f_{L_2}$  als Fehlerquelle isoliert und damit der aktuelle ZK  $\hat{d} = 1$ , was einem Leck in Tank 2 von 5% entspricht.

## 6 Zusammenfassung

In diesem Beitrag wurde ein neuartiges Framework für die Prozessüberwachung von AP und den Transienten zwischen den AP basierend auf SVM Klassifizierung vorgestellt. Dafür wurde ein dreiteiliges Verfahren entwickelt, welches im ersten Schritt die Merkmale für die Fehlerdiagnose generiert. Dafür wird der Prozess in Phasen unterteilt und für jede Phase einfache Merkmale wie die Phasendauer oder der Mittelwert einer Größe

errechnet. Das so entstehende System wird durch ein Hybrid Modell beschrieben. Für jede Phase wird eine FD mit einer 2K-SVM entworfen und der Fehler mit der neu vorgestellten ZGR Methode mit einer 1K-SVM isoliert. Der Fehlerzustand wird über die Distanz zur Trennebene des isolierten Fehlers aus der 2K-SVM für die FD gewonnen. Die Fehlerdiagnose wird dabei am Ende einer Phase ausgeführt. Im letzten Schritt werden die Ergebnisse der letzten Phasen genutzt um bei mehreren möglichen Fehlerquellen die richtige zu identifizieren. Das Framework zeichnet sich durch seine Einfachheit, dem geringen online Ressourcenbedarf und dem modularen Aufbau aus, der es ermöglicht Teile des Frameworks auszulagern. Es ist die Absicht des Autors das Framework in Prozessnahe Komponenten mit begrenzten Ressourcen zu implementieren (z.B. in einer SPS). Der Nutzen des Verfahren wurde an einem weit verbreiteten Fehlerdiagnose Benchmark anhand eines Batch Prozess bewiesen.

## Literatur

- [1] B.E.Boser, B. E. & Guyon, I. M. & Vapnik, V. N.: *A training algorithm for optimal margin classifiers*, Proceedings of the fifth annual workshop on Computational learning theory, ACM, 1992.
- [2] Cristianini, N. & Shawe-Taylor, J: *An Introduction to Support Vector Machines: And Other Kernel-Based Learning Methods*, Cambridge University Press, 2000.
- [3] Ding, S. X.: *Model-based Fault Diagnosis Techniques*, Advances in Industrial Control, Springer Berlin Heidelberg, 2013.
- [4] Jadine, A. K. & Lin, D. & Banjevic, D.: *A review on machinery diagnostics and prognostics implementing condition-based maintenance*, Mechanical Systems and Signal Processing 20(7), ScienceDirect, 2006.
- [5] Louen, C. & Ding, S. X. & Kandler C.: *A new Framework for Remaining Useful Life Estimation Using Support Vector Machine Classifier*, Conference on Control and Fault-Tolerant Systems (SysTol) 2013, IEEE, 2013.
- [6] Schölkopf, B. & Platt, J. C. & Shawe-Taylor, J. & Smola, A. J. & Williamson, R. C.: *Estimating the Support of a High-Dimensional Distribution*, Neural Computation 13, Massachusetts Institute of Technology, 2001.
- [7] Widodo, A. & Yang, B.-S.: *Support vector machine in machine condition monitoring and fault diagnosis*, Mechanical Systems and Signal Processing 21(6), ScienceDirect, 2007.
- [8] Yao, Y. & Gao, F.: *A survey on multistage/multiphase statistical modeling methods for batch processes*, Annual Reviews in Control 33, ScienceDirect, 2009.